

盲源分离和盲反卷积

刘 琚¹, 何振亚²

(1. 山东大学信息科学工程学院, 山东济南 250100; 2. 东南大学无线电工程系, 江苏南京 210096)

摘 要: 盲信号处理是信号处理领域的热点研究问题, 盲源分离和盲反卷积是盲信号处理的重要组成部分近年来取得许多重要进展. 本文主要介绍盲源分离和盲反卷积的基本模型、数学原理和研究进展; 分析了各种方法的特点并指出了进一步的研究方向.

关键词: 盲源分离; 盲反卷积; 独立分量分析

中图分类号: TN911.7

文献标识码: A

文章编号: 0372-2112 (2002) 04-0570-07

A Survey of Blind Source Separation and Blind Deconvolution

LIU Ju¹, HE Zhen-ya²

(1. College of Information Science and Engineering, Shandong University, Jinan, Shandong 250100, China;

2. Department of Radio Engineering, Southeast University, Nanjing, Jiangsu 210096, China)

Abstract: Blind signal processing is attractive in the community of signal processing. Blind source separation and Blind deconvolution are main components in blind signal processing and advances have been developed in recent years. We introduce the basic model of blind source separation and blind deconvolution, the mathematical principle of them, and the latest progresses in research. We then analyze the characteristic of typical algorithms and point out the future development.

Key words: blind source separation; blind deconvolution; independent component analysis

1 引言

近几年, 盲源分离和盲反卷积方法的研究已经成为信号处理领域一个引人注目的热点问题. 盲源分离 (Blind Source Separation-BSS), 是指在不知源信号和传输通道的参数的情况下, 根据输入源信号的统计特性, 仅由观测信号恢复出源信号各个独立成分的过程. 这一过程又称为独立分量分析 (Independent Component Analysis-ICA). 现在所指的盲源分离通常是对观测到的源信号的线性瞬时混迭信号进行分离. 当考虑到时间延迟的情况下, 观测到的信号应该是源信号和通道的卷积, 对卷积混迭信号进行盲分离通常称为盲反卷积 (Blind Deconvolution-BD). 盲源分离和盲反卷积方法的研究在语音、通信、生物医学工程和地震等各个领域具有非常重要的理论价值和实际意义.

较早进行盲源分离方法研究的是 Herault 和 Jutten^[1], 他们提出了一种类神经盲源分离方法. 该方法基于反馈神经网络, 通过选取奇次的非线性函数构成 Hebb 训练, 从而达到盲源分离的目的. 该方法不能完成多于两个混迭源信号的分离, 非线性函数的选取具有随意性, 并且缺乏理论解释. Tong 和 Liu^[2]分析了盲源分离问题的可分离性和不确定性, 并给出一类基于高阶统计的矩阵代数特征分解方法. Cardoso^[3]提出了基于高阶统计的联合对角化盲源分离方法, 并应用于波束形

成. Comon^[4]系统地分析了瞬时混迭信号盲源分离问题, 并明确了独立分量分析的概念. 利用了可以测度源信号统计独立性的 Kullbak-Leibler 准则作为对比函数 (Contrast Function), 通过对概率密度函数的高阶近似, 得出用于测度信号各分量统计独立的对比函数, 并由此给出一类基于特征分解的独立分量分析方法. Sejnowski 和 Bell^[5]基于信息理论, 通过最大化输出非线性节点的熵, 得出一种最大信息传输的准则函数并由此导出一种自适应盲源分离和盲反卷积方法 (Infomax), 当该方法中非线性函数的选取逼近源信号的概率分布时可以较好地恢复出源信号. 该算法只能用于源信号峭度 (kurtosis) 大于某一值的信号的盲分离, 所以它对分离线性混迭的语音信号非常有效. Amari 和 Cichocki^[6]基于信息理论中概率密度的 Gram-Charlier 展开利用最小互信息 (Minimum Mutual Information-MMI) 准则函数, 得出一类前馈网络的训练算法, 可以有效分离具有负峭度的源信号, 算法具有等变 (equivariant) 特性, 即不受混迭矩阵的影响. Hyvarinen^[7]基于源信号非高斯性测度 (或峭度), 给出一类定点训练算法 (fixed-point), 该类算法可以提取单个具有正或负峭度的源信号. 该类准则函数和算法与 Grolami 和 Fyfe^[8]的外推投影追踪 (Exploratory Projection Pursuit-EPP) 算法具有相似性.

在对线性瞬时混迭信号盲源分离方法进行研究的同时,

人们对卷积混迭信号盲分离(盲反卷积)方法也进行了研究。Platt 和 Faggin^[9]将 H-J 算法推广到具有时间延迟和卷积混迭情况。Yellin 和 Wensten^[10]给出了基于高阶累积量和高阶谱多通道盲反卷积方法,通过递归特征分解可以同时进行盲系统参数辨识和盲反卷积。由于用到高阶累积量和需计算高阶谱,该方法所需运算量极大。Thi 和 Jutten^[11]同样利用四阶累积量或四阶矩函数,给出了卷积混迭信号盲分离的自适应训练方法。K. Tokkola^[12]提出了一个反馈网络结构,将 Infomax 算法推广到更广泛的情况,即具有时间延迟的源的混迭或卷积混迭信号的盲分离。Lee 和 Bell^[13]将基于信息最大传输或最大似然算法得出的盲源分离训练算法变换到频率域,并利用 FIR 多项式代数技术进行盲反卷积。

最近人们已经开始研究存在噪声的混迭和非线性混迭信号的盲分离问题。非线性盲分离比线性情况的分离难度更大。较早涉及的非线性混迭信号盲分离的是 Burel^[14],他用一个两层感知器和基于误差后向传输思想的无监督训练算法通过梯度下降算法优化统计独立的测度函数,得到一种盲分离算法,可以用于非线性混迭信号的盲分离。1996 年 Parra^[15]提出一类前向信息保持非线性结构映射网络,通过最小化输出互信息,减小输出各个分量间的剩余度,从而可以得到非线性独立成分。Pajunen, Hyvarinen 和 Karhunen^[16]用自组织映射(Self-organization Map-SOM)网络从非线性混迭信号中恢复源信号,该算法可以不考虑非线性混迭的形式,但其网络复杂性呈指数增长且在分离连续源时存在严重的插值误差。Yang 和 Aman^[17]利用两层感知器网络结构,通过最大熵和最小互信息作为测度独立的代价函数,提出了信息后向传输的训练方法。当合理选择非线性函数时该算法可以分离出一些特定非线性混迭的源信号。Taleb 和 Jutten^[18]提出了一种非线性混迭信号盲分离算法,可以对被称为后非线性混迭的信号进行盲分离。

由于存在噪声的分离是困难的,以上方法都没考虑噪声影响。有人把带噪声混迭看作一种非线性,所以现有的一些带噪声混迭信号盲分离方法都是利用非线性方法。Moulines 和 Cardoso^[19]利用逼近最大似然方法进行带噪声混迭信号的盲分离和盲反卷积,其中用于处理不完全数据的期望最大化(Expectation Maximizing-EM)方法作为主要数学工具;Hyvarinen^[20]指出,在混迭过程中存在噪声意味着观测数据和源信号的关系存在非线性,他们用了独立成分和混迭矩阵的联合最大似然估计方法。

在盲源分离理论上的研究已经取得一定进展之后,人们开始研究盲源分离方法的实际应用。Lee 和 Bell^[21]将基于信息最大传输或最大似然算法得出的盲源分离训练算法进行盲反卷积,并用于真实记录的语音信号分离。实验证明分离后的语音识别率得到提高。Karhunen 和 Hyvarinen^[22]等将神经网络盲分离算法用于提取图像的特征和分离医学脑电信号。Makeig, Jung 和 Bell^[23]等用盲源分离方法将从脑电(electroencephalographic-EEG)信号中记录的事件相关的相应数据分解为与传感器数量相等的成分,同组的 McKeown^[24]等还将 ICA 用于分析核磁共振成像数据集。Sahlin 和 Broman^[25]在移动通信的手机中增加一个麦克风,用信号分离算法来改善通信中

号传输之前的信噪比。

国内近期关于盲信号处理理论和应用技术的研究几乎是与国际上同步进行的。凌雯亭^[26]和何振亚^[27~30]在国内较早地注意了盲信号处理研究。凌雯亭^[26]利用反馈式神经网络根据 Hebbian 的学习算法,实现了近场情况下一般信号的盲分离,并对算法的渐近收敛性和实现信号分离状态的稳定性进行了讨论。何振亚^[27~30]在基于特征分析和高阶谱的盲源分离和盲反卷积方法研究中,提出了一系列新的基于高阶统计和信息理论的判据和算法。在盲系统参数估计和盲波束形成等方面的也取得许多很好的研究成果。最近胡光锐^[31]也开始了盲语音分离问题的研究,并提出了基于高斯混合模型概率密度估计的语音分离方法。

2 盲源分离和盲反卷积系统的数学模型

考虑如下线性瞬时混迭信号系统模型:

$$x(t) = As(t) + n(t) \quad (1)$$

其中 $x(t)$ 是 M 维观测信号矢量, $s(t)$ 为 N 维未知源信号矢量, $n(t)$ 为 M 维加性观测噪声, A 为未知混合矩阵,每个观测信号 $x_i(t)$ 都是 N 个未知源信号 $s_i(t)$ 的瞬时线性组合。

盲源分离问题就是求一分离矩阵 W ,使得通过它可以仅从观测信号 $x(t)$ 来恢复出源信号 $s(t)$,设 $y(t)$ 为源信号的估计矢量,则分离系统输出可通过如下数学模型表示:

$$y(t) = Wx(t) \quad (2)$$

更一般地,传感器测得的信号是源及其滤波和延迟的混迭信号的线性组合,通常称为卷积混迭。无噪声多通道卷积混迭信号的数学模型可以用下式所示:

$$x(t) = A(z)s(t) = \sum_{k=-\infty}^{\infty} A(k)s(t-k) \quad (3)$$

式中 $x(t)$, $s(t)$ 同瞬时混迭式; $A(k)$ 为未知滤波混迭矩阵, $A(z)$ 为其 z 变换;观测信号 $x(t)$ 是源信号 $s(t)$ 通过 $A(k)$ 的卷积混合,所以矩阵序列 $\{A(k)\}$ 又称为冲激响应。

现有的多通道盲反卷积方法大都是仅通过观测信号 $x(t)$ 估计通道冲激响应 $\{A(k)\}$ 进而恢复源信号。我们可以直接给出盲反卷积(盲均衡)模型:

$$y(t) = \sum_{k=-\infty}^{\infty} W(k)x(t-k) = W(z)x(t) \quad (4)$$

其中 $y(t)$ 为均衡输出矢量; $W(z)$ 称为均衡器, $W(k)$ 为均衡器系数矩阵。

由于带有未知分布的噪声的混迭信号盲分离是困难的,在以上两类模型的研究中现在一般都暂不考虑它的影响。另外,除了线性瞬时和卷积混迭以外,实际系统中还存在更一般的非线性混迭情况。由于非线性混迭信号盲分离的复杂性,现在还仅对几类特殊的模型进行了研究,如 Pajunen^[16], Yang^[17] 和 Jutten^[18]等的模型和算法。

在盲源分离和盲反卷积问题中,由于源信号和混迭系统均未知,如果没有任何先验知识,要想仅从观测信号恢复出源信号是极为困难的。为使问题可解,根据实际存在的情况,文献[4],[32]分别分析了无噪声情况下瞬时混迭和卷积混迭模型并指出,在符合某些假设的条件下这两类问题都是可解的。

但恢复信号各分量的幅度和排列次序同源信号相比是不确定的。

3 典型方法综述

3.1 盲源分离方法

在已有的盲源分离方法中,都是利用了源信号统计独立的假设,主要的方法是基于高阶统计和信息理论的方法。

3.1.1 基于高阶统计的方法 现有的大多数信号处理方法都是基于二阶统计的。对高斯信号,不相关和独立是等价的。但对非高斯信号,独立是比不相关更强的条件,它意味着在包含二阶统计在内的所有更高阶统计上相互独立。如果没有任何其他约束条件,仅通过二阶统计不足以解决盲源分离这一问题。所以从研究盲源分离问题的开始阶段,人们就试图寻求所熟悉的二阶统计之外的解决方案,并取得进展。

Cardoso^[33]较早地用四阶矩进行盲源分离(Fourth-Order Blind Identification-FOBI),提出了一种简单的正交和加权两步代数算法,独立源成分可以较容易地作为改进了的协方差的特征矢量被辨识出来,但该算法未能辨识相同概率分布的成分;Tong和Liu^[2]等基于以上算法,首先通过正交变换,然后对观测到的混迭信号的四阶矩进行奇异值分解(SVD),得到一类扩展的四阶盲辨识(Extended FOBI-EFOBI)和多未知信号提取算法(Algorithm for Multiple Unknown Signals Extraction-A-MUSE);Cardoso^[3]还提出了基于四阶累积量的联合对角化(Joint Approximate Diagonalisation of Eigen-matrices-JADE)进行盲波束形成的方法,通过联合对角化累积量矩阵,使得对所有的累积量集合处理的计算效率同基于特征分解的技术类似。

基于高阶统计的自适应盲源分离算法大致可分为两类:准则函数或训练算法中不明确含有高阶累积量的算法-称为隐累积量算法(Algorithms Using Higher-Order Cumulants Implicitly);准则函数或训练算法中含有高阶累积量的算法-称为显累积量算法(Algorithms Using Higher-Order Cumulants Explicitly)。

隐累积量算法^[1,33,34] 这类方法中较典型的是由Herault和Jutten较早提出的神经网络算法^[1],通常称为HJ算法。他们选用递归网络结构,分离网络输出为

$$y(t) = x(t) - W(t)y(t)$$

其权系数训练公式为:

$$\frac{dw_{ji}(t)}{dt} = \mu(t) f[y_i(t)] g[y_j(t)] \quad (5)$$

其中 $f[y_i(t)]$ 和 $g[y_j(t)]$ 为一类奇函数。

HJ算法的得出没有明确的误差函数,使该误差函数的全局最小化就可以得问题的解。Cichocki^[32]指出,严格来说HJ算法实际上是类似的二阶算法的经验推广,他们还将这种算法推广到前馈线性网络结构,使算法鲁棒性(Robustness)增强。实际上,用非线性函数代替线性函数就是在算法中隐含地引入了高阶统计。

显累积量算法^[35~39] 这是一类以简单的高阶统计峭度(Kurtosis)作为代价函数,利用随机梯度算法来得到分离阵 W 的自适应训练算法,通常称为基于峭度极值的算法。设对第 i 个源信号分量 $s_i(t)$,它的没有归一化的峭度定义为:

$$Kurt(s_i(t)) = c_4[s_i^4(t)] = E[s_i^4(t)] - 3\{E[s_i^2(t)]\}^2 \quad (6)$$

对高斯信号,峭度 $Kurt(s_i(t)) = 0$ 。当 $Kurt(s_i(t)) < 0$ 时,称源信号 $s_i(t)$ 为亚高斯(Sub-Gaussian)的,其概率分布比高斯信号的要平;当 $Kurt(s_i(t)) > 0$ 时,称 $s_i(t)$ 为超高斯(Super-Gaussian)的,其概率分布比高斯信号的要尖。所以,峭度可以用来衡量信号的高斯性,定义峭度作准则函数,也就是用它来衡量信号与高斯分布的距离。这是因为在盲源分量问题中,观测信号是源信号的线性叠加,根据统计理论,其高斯性应增强;信号分离的过程,就是网络输出的各分量非高斯性增强的过程。

这类算法通常需要预白化(pre-whiten),从而有四阶累积量 $c_4[s_i^4(t)] = E[s_i^4(t)] - 3\{E[s_i^2(t)]\}^2$ 。准则函数简化定义为:

$$\Phi(y(t)) = \sum_{i=1}^N E[y_i^4(t)] \quad (7)$$

对该准则函数的最大化(对正峭度源)或最小化(对负峭度源)可求得分离阵,但不能同时分离具有正峭度和负峭度的源信号,而且需预先知道峭度符号。目前已有的Karhunen等人提出的非线性PCA类算法^[39]和Cardoso等的等变自适应算法^[38]都属于此类算法。Oja和Hyvarinen提出的定点(fixed-point)算法^[7]虽解决了这个问题,但由于是串行工作,网络不能同时输出所有分离的信号,如需分离 N 个源需 N 次执行该算法。

3.1.2 基于信息理论的方法 盲源分离问题也引起人工神经网络社会的广泛关注^[35~37,40~43]。因为分离网络事实上为一线性前馈神经网络,完全可以用神经网络的理论和方法来求解。此时,盲源分离就是发展一个自适应权更新规则以使网络输出尽可能独立,所以这类网络又称独立分量分析网络。

从信息科学的角度出发,信息论是解决这类问题的一个重要的理论工具,而且在生物信息处理的背景下可获得合理的解释。Linsker^[44]认为,神经网络应从其输入中获取最大信息量并导出了无监督训练(Infomax)算法,以最大化神经网络输入和输出之间的互信息。这种信息最大化传输准则,在感知器处理的早期起着重要作用,它提供了动物感知神经对环境的自适应的一种模型。Infomax算法与Barlow^[45]提出的在神经元中作为编码策略的冗余度降低原理密切相关,这种策略将每一个神经元编码为与整个输入整体中其他神经元尽可能独立的特征。Nadal和Parga^[46]指出,在低噪声情况下,最大化一个神经网络输入输出之间的互信息就意味着输出分布是可以分解的,即多变量密度函数可以分解为各边缘概率密度函数的乘积。此时输出各分量相互独立。因此可以这样认为,通过独立分量分析进行盲源分离,就是使网络输入输出之间获得最大信息传输并使输出互信息为零。

Bell和Sejnowski^[15]率先将盲源分离问题放在信息理论框架之下。他们将Infomax原理,推广到相互独立的任意分布的非线性输入单元,针对单层线性前馈神经网络,得出一个可以进行盲源分离和盲反卷积的自适应随机梯度训练规则,从神经计算(神经信息处理)的角度看,这似乎比基于累积量的准则更具合理性。

现阶段基于信息理论准则的自适应盲源分离算法研究大致可分为最大信息传输(Information Maximization-Infomax),最大

似然估计 (Maximum Likelihood Estimation-MLE) 和输出互信息最小化 (Minimum Mutual Information-MMI) 三类。

信息最大化 (Infomax) 算法^[5]: 利用信息最大化原理进行盲源分离就是最大化输出熵, 所以又称最大熵 (Maximum Entropy-ME)。对一单层线性前馈神经网络, 简单的最大化将使输出熵发散至无穷。实际的 Infomax 盲分离算法是最大化经过非线性结点输出 $u(t) = g(y(t)) = g(Wx(t))$ 的熵。因此, 准则函数定义为:

$$\phi_{ME}(W) = H(u) = H(g(Wx)) \quad (8)$$

式中 $H(u)$ 为微分熵, $[g(y)]_i = g_i(y_i)$ 为非线性函数, 它将一实数映射到区间 $[0, 1]$, 并且为单调升函数。当源分离得以完全实现时, 它就应该是源分量的概率分布函数。上式对 W 最大化, 可得权系数 (分离阵) 的更新规则:

$$W \leftarrow (W^T)^{-1} - (y) x^T \quad (9)$$

其中 $(y)^T$ 为一梯度矢量。Bell^[5] 的 Infomax 算法中选择非线性函数 $[g(y)]_i = g_i(y_i)$ 为固定的 Sigmoid 函数。这相当于预先限定了源信号的分布, 所以该算法只能分离具有正峭度源的混迭信号。

最大似然估计 (MLE) 算法: 当源信号得以完全分离时, Infomax 算法中的非线性项就是假设的未知源信号的概率分布函数。Pearlmutter 和 Parra^[47] 通过定义多变量密度函数和在线参数估计将最初的 Infomax 算法进一步推广, 得到最大似然估计算法, 使得可分离源的类型范围得以扩大。

最大似然估计是利用已经获得的观测样本来估计样本的真实概率密度 $p(x)$ 。给定参数矢量, 通过某一准则获得的估计密度 $\hat{p}(x, \cdot)$ 充分逼近真实密度 $p(x)$ 。可以用测度两个概率密度之间距离的 Kullback-Leibler 散度 $K(\cdot, \cdot)$ 作为优化准则。考虑到 $x(t) = W^{-1}y(t)$, 这一准则可以用如下似然函数表示:

$$\phi_{MLE}(W, \cdot) = -\log |W| - \sum_{i=1}^N \log f_i(y_i; \cdot) \quad (10)$$

该准则和最大熵准则具有类似的形式, 所以其权系数矩阵 W 的更新规则同 Infomax 训练算法, 所不同的是最大似然准则的出发点是已知的观测样本, 而且作为输出概率密度函数的估计, 这儿的 $f_i(y_i; \cdot)$ 为一组高斯核函数的加权和。

Gaeta^[48] 提出了最大似然盲分离算法, 该类算法或基于高阶统计或预先给定一个特定的分离函数。Pham^[49] 提出了和上述算法类似的多变量密度估计最大似然估计盲源分离算法。Cardoso^[50] 指出 Infomax 和 MLE 算法是等价的。

基于最小互信息 (MMI) 算法: Amari^[6] 等将网络输出各个分量的互信息作为盲源分离的判据, 得到一种自适应训练规则。算法中利用概率密度的 Gram-Charlier 展开来逼近各输出分量的边缘概率密度函数, 引入了自然梯度 (相对梯度) 以提高训练效率和改善算法收敛性能。

根据香农信息理论关于互信息的定义, 考虑到线性关系 $y(t) = Wx(t)$, 可得基于最小输出互信息的准则函数:

$$\phi_{MI}(W) = \sum_{i=1}^N H(y_i) - \log |det(W)| - H(x) \quad (11)$$

该式的最小化得到分离矩阵 W , 使 $y(t)$ 趋于独立。当用梯度

法求解时式中右边最后一项由于与 W 无关可以被省去。

除了用 Gram-Charlier 展开逼近概率密度函数, Amari 的主要贡献还在于算法的得出引入了自然梯度 (Natural Gradient) 的概念 (Cardoso^[38] 和 Pham^[49] 称相对梯度 - Relative Gradient)。相对梯度或自然梯度定义为^[38, 49]:

$$\frac{dW}{dt} = - (t) \nabla \phi(W) W = - (t) \frac{\partial \phi(W)}{\partial W} W^T W \quad (12)$$

根据自然梯度下降法, 得到的基于最小互信息准则的盲源分离矩阵的训练规则:

$$W \leftarrow [I - (y) y^T] W \quad (13)$$

式中 (y) 为根据 Gram-Charlier 展开得出的关于 $y(t)$ 及其三阶和四阶累计量的函数。

从信息理论的意义分析, 以上三种准则没有本质上的区别。Pearlmutter 和 Parra^[47] 及 Cardoso^[50] 已经指出 Infomax 和 MLE 算法是等价的。Obradovic^[51] 的分析表明, 当 Infomax 的输出非线性函数的参数足够丰富时, 基于 Kullback-Leibler 作为信息冗余度测度的 ICA 算法和 Infomax 得到相同的解。由此, 基于信息理论的三类主要算法 ME (Infomax), MLE 和 MMI 是等价的, 所以 Lee 和 Grolani^[52] 等将他们在信息理论框架下进行了统一。

3.2 盲反卷积方法

较早的盲反卷积方法可以追溯到 Sato^[53], Godard^[54] 和 Benveniste^[55] 等的 Bussgang 类算法^[56], 他们的算法以及后来的盲均衡算法都是利用通信系统中数字信号的常模量 (Constant Modulus) 特性, 主要是针对单通道情况进行源信号的恢复。自从 Herealt 和 Jutten 的用于瞬时混迭信号盲分离的在线自适应算法^[11] 出现以后, 大多卷积混迭信号盲分离方法都是瞬时混迭信号盲分离算法的直接扩展。Platt 和 Faggin^[10] 以及 Nomura^[57] 将盲源分离方法 HJ 算法推广到具有时间延迟和卷积混迭的情况。Yellin 和 Wensten^[10] 给出了基于高阶累计量和高阶谱多通道盲反卷积方法, 通过递归特征分解可以同时进行盲系统参数辨识和盲反卷积, 但该方法由于用到高阶谱积累和需计算高阶谱, 运算量极大。Thi 和 Jutten^[11] 同样利用四阶谱积累或四阶矩函数, 给出了卷积信号盲分离的自适应训练方法。Tökkola^[12] 提出了一个反馈网络结构将 Infomax 算法推广到更广泛的情况, 即具有时间延迟的源的混迭或卷积混迭信号的盲分离。Lee 和 Bell^[13] 将基于信息最大传输或最大似然算法得出的盲源分离训练算法变换到频率域, 并利用 FIR 多项式代数技术进行盲反卷积。

HJ 算法的扩展^[9, 57]: 这类算法是瞬时混迭盲源分离 HJ 网络训练算法的直接推广。针对反馈分离网络和卷积混迭模型, 卷积混迭信号的反馈分离网络输出为:

$$y(t) = x(t) - \sum_{k=0}^L W(k) y(t-k) \quad (14)$$

Platt 和 Faggin^[9] 为这类网络确定了用来进行优化的理论准则-最小输出功率原理, 即当独立分量得以分离, 则信号的功率达到最小, 由此利用梯度下降法得到该网络的训练公式, 它恰好是 HJ 算法的推广:

$$w_{ij}(k) = y_i(t) y_j(t) \quad (15)$$

累积量算法的扩展^[11] 这是一种基于互累积量消失的自适应盲反卷积算法. 该算法利用了盲源分离的经验公式. 直接将盲源分离的情况扩展到盲反卷积. 公式在形式上和扩展的 HJ 方法类似, 而 HJ 公式中的非线性函数用四阶互累积量 $c_{31}(y_i^3(t)y_j(t))$ 和 $c_{13}(y_i(t)y_j^3(t))$ 代替, 训练公式为:

$$w_{ij}(k) = -c_{31}(y_i(t)y_j(t-k)) \quad (16)$$

信息理论算法扩展^[12,57]: 对瞬时混迭信号模型, Infomax 方法是较成功的盲源分离方法之一. Torkkola^[12] 将 Infomax 算法推广到卷积混迭的情况, 得出了一个局部训练算法 (仅有两个源的情况). 该算法通过因果滤波器最大化输出熵来最小化两个输出之间的互信息. 基于最大信息传输原理, 可以得出直接滤波零延迟权系数, 直接滤波非零延迟权系数和反馈交叉滤波权系数的训练公式. 而对更一般的卷积混迭情况, Lee^[13] 给出了反卷积系统滤波器权系数的公式:

$$W(0) = [I + uy^T] W(0) \quad (17)$$

$$W(k) = [uy^T(t-k) W(k)] \quad (18)$$

基于 FIR 多项式矩阵代数的分离矩阵的频域训练算法

Lambert^[58] 在他的博士论文中发展了 FIR 滤波器多项式代数的理论, 并通过仿真实例表明该理论是解决多通道盲源分离问题的一种有效工具. 应用 FIR 多项式矩阵代数的基本思路是扩展标量矩阵代数到时域的滤波器矩阵代数 (或频域的多项式矩阵). 利用这一理论可以得到频域扩展的 Infomax 算法:

$$W = [W^{-H} + FFT(u)X^H] \quad (19)$$

其中“ H ”表示复共轭; W 为滤波器矩阵, X 和 Y 为频率域多传感器信号块.

3.3 非线性盲源分离方法

在实际的环境里, 观测到的混迭信号可能是经过非线性混迭得到的, 此时线性混迭信号盲分离的方法不再适用. 如果把非线性混迭模型仍视为线性混迭并利用线性 ICA 方法求解, 可能导致错误的结果. 因而, 作为一般的模型, 非线性混迭信号的盲分离问题的研究近来也引起许多研究者的注意^[15,59~61].

由于完全非线性混迭盲分离问题的复杂性, 现有的非线性混迭信号盲分离算法研究的都是后非线性混迭 (post-nonlinear mixture-PNL) 的情况, 即对源信号线性混迭后再加以非线性.

已经进行的研究可以分为两类: 一类是直接将有线性混迭分离方法通过引入非线性进行扩展, 使之适用于非线性混迭的情况. 这一类算法主要针对后非线性混迭情况, 对不同的目标函数进行优化. 如 Taleb 和 Jutten^[18] 提出了基于输出互信息的后非线性混迭信号的盲分离方法, 该方法分别自适应地估计非线性和线性部分, 它和 Lee^[59] 提出的基于信息最大化准则的方法类似; Yang^[17] 等提出的信息后向传输方法, 包含了以上两种准则, 但可以分离通道间存在交叉非线性混迭的情况, 即对后非线性后再对 $f(s(t))$ 进行线性混迭的信号作为观测信号, 此仍然属于特定的混迭情况. 另一类则是通过提取非线性特征等方法直接进行分离. 网络的结构与源信号的拓扑结构等效时, 在某些条件下自组织特征映射 (Self-

Organization Feature Map-SOM) 表示了非线性混迭的逆. 将观测信号映射到规则的输出网格, 每一个 SOM 网络输出的坐标表示了一个源. 这类方法不受混迭模型的限制, 可以适用于完全非线性混迭的情况. 例如, Pajunen^[16] 等利用 SOM 神经网络从非线性混迭的观测信号中提取源信号; Lin^[60] 等通过修改 SOM 算法, 发展了一个网络, 可以提取源分布的局部几何结构, 对超高斯源信号可以快速分离. 基于 SOM 的方法的优点是它可以提供非参数解, 但网络的复杂性随着源数目的增加呈指数增长, 而且存在严重的插值误差^[17].

4 总结与展望

到目前为止, 大多数从事盲信号处理研究的人都局限于方法的研究, 还有许多理论上的问题需要解决, 如盲分离算法的全局收敛性和渐近稳定性等问题的分析以及算法的鲁棒性研究等. 要想取得理论上的突破, 需要更多的基础理论方面的学者的参与. 我们认为在今后应该对以下问题进一步研究:

(1) 带噪声混迭信号的盲分离问题. 由于在盲信号处理中, 存在太多的未知条件, 带噪声的混迭信号盲分离是困难的. 现在研究的大部分盲源分离或盲反卷积算法, 大都假设无噪声情况或把噪声看作一个独立源信号. 在高阶统计方法中, 由于高斯信号高阶累积量为零, 所以可以假设加性高斯噪声存在. 已有的盲分离方法在什么情况下可以应用到一般的噪声混迭模型, 是有待研究的问题.

(2) 虽然盲源分离是从所谓的“鸡尾酒会”问题引出的, 但是这个问题还远没有很好地解决. 由于这涉及到多通道卷积混迭系统和盲反卷积系统的稳定性和相位不确定性问题. 尤其是源的数目未知时盲反卷积问题以及带噪声的情况, 由于需要太多的参数来描述系统, 这即使在非盲的情况下的反卷积的研究都是非常困难的, 盲反卷积问题的研究远比线性瞬时混迭信号的盲分离要复杂得多.

(3) 无论是盲源分离还是盲反卷积, 现在研究都假设传感器的个数不少于源信号的个数, 对源信号个数多于传感器个数的问题如何解是又一个困难的问题.

(4) 现在的非线性混迭信号盲源分离方法研究的只是在极特殊情况下的非线性混迭的情况. 对更一般的非线性混迭信号的可分离性以及分离的充要条件需作进一步的研究.

(5) 非平稳混迭信号的盲分离问题. 许多情况下源信号可能是非平稳的, 例如源可能消失后再出现. 如何利用信号的非平稳特性进行盲分离是解决这类问题的一个方向.

参考文献:

- [1] Jutten C, Herault J. Blind separation of sources, Part I: An adaptive algorithm based on neuromimetic [J]. Signal Processing, 1991, 24(1): 1 - 10.
- [2] Tong L, Liu R, Soon V C, et al. Indeterminacy and Identifiability of Blind Identification [J]. IEEE Trans on Circuits and systems, 1991, 38(5): 499 - 506.
- [3] Cardoso J F. Blind Beamforming for Non-Gaussian Signals [J]. IEEE Proceedings-F, 1993, 140(6): 224 - 230.

- [4] Comon P. Independent component analysis, a new concept ? [J]. Signal Processing, 1994, 36(3) : 287 - 314.
- [5] Bell A J, Sejnowski T J. An information-maximization approach to blind separation and blind deconvolution [J]. Neural Computation, 1995, 7(6) : 1129 - 1159.
- [6] Amari S, Cichocki A, Yang H H. A new learning algorithm for blind signal separation [A]. Advances in Neural Information Processing Systems [C]. Cambridge, MA: MIT Press, 1996, 8: 657 - 663.
- [7] Hyvarinen A, Oja E. A fast fixed-point algorithm for independent component analysis [J]. Neural Computation, 1997, 9(7) : 1483 - 1492.
- [8] Grolani M, Fyfe C. An extended exploratory projection pursuit network with linear and nonlinear anti-Hebbian lateral connections applied to the cocktail party problem [J]. Neural Networks, 1998, 10(9) : 1607 - 1618.
- [9] Platt C, Faggin F. Networks for the separation of sources that are superimposed and delayed [A]. Advances In Neural Information Processing Systems [C]. 1991, 730 - 737.
- [10] Yellin D, Wensten E. Criteria for multichannel signal separation [J]. IEEE Trans Signal Process, 1994, 42(8) : 2158 - 2168.
- [11] Thi H N, Jutten C. Blind source separation for convolutive mixtures [J]. Signal Processing, 1995, 45(2) : 209 - 229.
- [12] Tokkola K. Blind Separation of delayed sources based on information maximization [A]. in Proc of ICASSP [C]. Atlanta: ICASSP, 1996, 3509 - 3512.
- [13] Lee T W, Bell A J, Lambert R H. Blind separation of delayed and convolved sources [A]. Advances In Neural Information Processing Systems [C]. Cambridge MA: MIT Press 1997, 758 - 764.
- [14] Burel G. Blind separation of sources: A nonlinear neural algorithm [J]. Neural Networks, 1992, 5(6) : 937 - 947.
- [15] Parra L C. Symplectic nonlinear component analysis [A]. Advances in Neural Information Processing Systems [C]. Cambridge MA: MIT Press, 1996, 437 - 443.
- [16] Pajunen P, Hyvarinen A, Karhunen J. Nonlinear blind source separation by self-organizing maps [A]. in Progress in Neural Information Processing [C]. Berlin: Springer, 1996, 1207 - 1210.
- [17] Yang H H, Amari S, Cichocki A. Information back-propagation for blind separation of sources from non-linear mixture [A]. in Proc ICNN [C], Houston: ICNN1997: 2141 - 2146.
- [18] Taleb A, Jutten C. Source separation in post nonlinear mixtures: An entropy-based algorithm [A]. in Proc of ICASSP [C]. Washington: ICASSP, 1998, 2089 - 2092.
- [19] Moulines E, Cardoso J F, Gassiat E. Maximum likelihood for blind separation and deconvolution of noisy signals using mixture models [A]. in Proc Of ICASSP [C]. Washington: ICASSP, 1998, 3617 - 3620.
- [20] Hyvarinen A. Noisy independent component analysis [A]. maximum likelihood estimation, and competitive learning, in Proc Of ICNN [C]. Alaska: ICNN, 1998, 2282 - 2286.
- [21] Lee T W, Bell A J, Orghmeister R. Blind source separation of real world signals [A]. in Proc of ICNN [C]. Houston: ICNN, 1997, 2129 - 2134.
- [22] Karhunen J, Hyvarinen A. Application of neural blind separation to signal and image processing [A]. in Proc ICASSP [C]. Germany: Munich, 1997, 131 - 134.
- [23] Makeig S, Jung T P, Bell A J, et al. Blind separation of auditory event-related brain responses into independent components [J]. in Proc Natl Acad Sci, 1997, 94: 10979 - 10984.
- [24] McKeown M J, Jung T P, Makeig S, et al. Spatially independent activity patterns in functional MRI data during the stroop color-naming task [J]. in Proc Natl Acad Sci, 1998, 95: 803 - 810.
- [25] Sahlin H, Broman H. Separation of real-world signals [J]. Signal Processing, 1998, 64(2) : 103 - 113.
- [26] 凌雯亭. 近场宽带信号源的盲分离 [J]. 电子学报, 1996, 24(7) : 87 - 92.
- [27] 何振亚, 刘琚, 杨绿溪等. 盲均衡和信道参数估计的一种 ICA 和进化计算方法 [J]. 中国科学(E 辑), 2000, 30(1) : 1 - 7.
- [28] 刘琚, 聂开宝, 何振亚. 线性混迭信号中独立源的盲提取 [J]. 应用科学学报, 2001, 19(3) : 24 - 29.
- [29] He Zhenya, Liu Ju, Yang Luxi. Blind separation of images using edge-worth expansion based ICA algorithm [J]. Chinese Journal of Electronics, 1999, 8(3) : 278 - 282.
- [30] He Zhenya, Yang Luxi, Liu Ju. Blind source separation using cluster-based multivariate density estimation algorithm [J]. IEEE Trans on Signal Processing, 2000, 48(2) : 575 - 579.
- [31] Yu X, Hu G R. Speech separation based on the GMM pdf estimation and the feedback architecture [A]. in Proc. Of the First International Workshop on Independent Component Analysis and Signal Separation [C]. France: Aussois, 1999, 353 - 357.
- [32] Tugnait K. Spatio-temporal signal processing for blind separation of multichannel signals [A]. in Proc of SPIE [C]. Orlando: SPIE, 1996, 88 - 103.
- [33] Cardoso J F. Source separation using higher order moments [A]. in Proc of ICASSP [C]. Glasgow: UK, 1989, 2109 - 2112.
- [34] Cichocki A, Unbehauen A. Robust neural networks with on-line learning for blind identification and blind separation of sources [J]. IEEE Trans Circuits and Systems, 1996, 43(11) : 894 - 906.
- [35] Hyvarinen A, Oja E. Independent component analysis by general nonlinear Hebbian-like learning rules [J]. Signal Processing, 1998, 64(3) : 301 - 313.
- [36] Oja E, Hyvarinen A. Blind signal separation by neural networks [A]. in Proc of ICONIP [C]. Hong Kong, 1996, 7 - 14.
- [37] Karhunen J. Neural approaches to independent component analysis and sources separation [A]. in Proc 4th European Symp. Artificial Neural Networks [C]. Belgium: Bruges, 1996, 249 - 266.
- [38] Cardoso J F, Laheld B H. Equivariant adaptive source separation [J]. IEEE Trans Signal Processing, 1996, 44(12) : 3017 - 3029.
- [39] Karhunen J, Wang L, Vigario R. Nonlinear PCA type approaches for source separation and independent component analysis [A]. in Proc. of ICNN [C]. Australia: ICNN, 1995, 995 - 1000.
- [40] Grolani M. An alternative perspective on adaptive independent component analysis algorithms [J]. Neural Computation, 1998, 10(8) : 2103 - 2114.
- [41] Amari S, Cichocki A. Adaptive blind signal processing-neural network approaches [J]. Proc of the IEEE, 1998, 86(10) : 2026 - 2048.
- [42] Lee T W, Grolani M. Independent component analysis using an extended infomax algorithm for mixed subgaussian and supergaussian sources [J]. Neural Computation, 1999, 11(2) : 417 - 441.

- [43] Hyvarinen A. Simple one-unit neural algorithms for blind source separation and blind deconvolution [A]. in Proc of ICONIP [C]. Hong Kong:ICONIP,1996. 1201 - 1206.
- [44] Linsker R. Local synaptic learning rules suffice to maximize mutual information in a linear network [J]. Neural Computation, 1992, 4(3): 491 - 702.
- [45] Barlow H B. Possible Principles underlying the transformation of sensory message, in Sensory Communication [M]. Cambridge MA: MIT press, 1961
- [46] Nadal J P, Parga N. Nonlinear neurons in the low-noise limit: a factorial code maximizes information transfer [J]. Network, 1994, 4: 295 - 312.
- [47] Pearlmutter B A, Parra L C. A context-sensitive generalization of ICA [A]. in Proc of ICONIP [C]. Hong Kong:ICONIP, 1996. 151 - 157.
- [48] Gaeta M, Lacoume J L. Sources Separation Without a priori Knowledge: The Maximum Likelihood Solution, Signal Processing V: Theories and Applications [M]. Elsevier, 1990.
- [49] Pham D T. Blind separation of instantaneous mixture of sources via an independent component analysis [J]. IEEE Trans Signal Processing 1996, 44(11): 2768 - 2779.
- [50] Cardoso J F. Infomax and maximum likelihood for blind source separation [J]. IEEE Signal Processing Letters, 1997, 4(4): 112 - 114.
- [51] Obradovic D, Deco G. Information maximization and independent component analysis: Is there a difference? [J]. Neural Computation, 1998, 10(8): 2085 - 2101.
- [52] Lee T W, Girolami M, Bell A J, Sejnowski T J. A unifying information-theoretic framework for independent component analysis [J]. Computers and Mathematics with Applications. 2000, 31(11): 1 - 21.
- [53] Sato Y. A method of self-recovering equalization for multilevel amplitude-modulation systems [J]. IEEE Trans on Commun, 1975, 23(6): 679 - 682.
- [54] Godard D N. Self-recovering equalization and carrier tracking in two-dimension data communication systems [J]. IEEE Trans on Commun, 1980, 28(11): 1867 - 1875.
- [55] Benveniste A, Goursat M. Blind Equalizers [J]. IEEE Trans on Commun, 1984, 32(8): 871 - 883.
- [56] Bellini S. Bussgang Techniques for Blind Deconvolution and Blind Equalization [M]. Englewood Cliffs: Prentice-Hall, 1994.
- [57] Nomura T, Eguchi M, et al. An extension of the herault-jutten network to signal including delays for blind separation [A]. in Proceedings of IEEE Workshop on Neural Networks for Signal Processing [C]. Kyoto, 1996.
- [58] Lambert R M. Multi-channel blind deconvolution: FIR Matrix Algebra and Separation of Multipath Mixtures [D]. California: University of Southern California, 1996.
- [59] Lee W T, Koehler B. Blind separation of nonlinear mixing models [A]. in Proc Of IEEE NNSP [C]. Florida, USA, 1997. 406 - 415.
- [60] Lin K, Grier D G, Cowan J D. Source Separation and Density Estimation by Faithful Equivariant SOM, Advances in Neural Information Processing Systems [M]. Cambridge MA: MIT Press, 1997.
- [61] Hyvarinen A, Pajunen P. On existence and uniqueness of solutions in non-linear independent component analysis [A]. in Proc of ICNN [C]. Alaska: ICNN, 1998. 1350 - 1355.

作者简介:



刘 琚 男, 1965 年 4 月生于山东临沂, 现为山东大学信息科学与工程学院教授, 博士生导师, 1982 年和 1989 年于山东大学电子工程系获理学学士和理学硕士学位, 2000 年于东南大学无线电工程系获工学博士学位, 已发表论文 30 余篇, 主要研究方向为盲信号处理、神经网络信息处理、图像复原和数字水印技术等。



何振亚 男, 1923 年生于江苏盐城, 东南大学无线电工程系教授、博士生导师, IEEE Fellow, 国家攀登计划项目首席科学家, 研究领域包括自适应信号处理, 多维信号处理, 神经网络、进化计算和混沌理论与应用等。